

Prediksi Produksi Kelapa Sawit Menggunakan Algoritma Support Vector Regression dan Recurrent Neural Network

Rezky Alfakhri*, Inggih Permana, Rice Novita, M Afdal

Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: ^{1,*}11950311576@students.uin-suska.ac.id, ²inggih.permana@uin-suska.ac.id, ³rice.novita@uin-suska.ac.id, ⁴m.afdal@uin-suska.ac.id

Email Penulis Korespondensi: 11950311576@students.uin-suska.ac.id

Submitted: 13/12/2024; Accepted: 29/12/2024; Published: 30/12/2024

Abstrak—Kelapa sawit adalah salah satu jenis tanaman perkebunan yang penting dan menjadi komoditas unggulan di Indonesia. PT. XYZ merupakan perusahaan yang bergerak dalam bidang penerimaan Tandan Buah Segar (TBS) untuk kemudian diolah menjadi Crude Palm Oil (CPO) dan Palm Kernel (PK). Selama ini, perusahaan melakukan analisis statistik dengan nilai koreksi 5% - 12% pada hasil produksi setiap bulannya dalam menargetkan hasil produksi. Namun, metode ini masih kurang, karena menggunakan perhitungan manual dan mempertimbangkan perkiraan dari pengalaman pribadi. Oleh karena itu, penelitian ini mengusulkan teknik data mining dengan algoritma Support Vector Regression (SVR) dan Recurrent Neural Network (RNN) untuk memprediksi hasil produksi dengan tepat. Pada penelitian ini, dilakukan pengujian pada hyperparameter SVR yaitu Kernel, C, Gamma, dan Epsilon. Sedangkan pada RNN, dilakukan pengujian pada optimizer, dan learning rate. Selain itu window size juga ditetapkan melalui rangkaian percobaan yaitu 3, 5, dan 7. Hasil perbandingan menunjukkan model RNN mengungguli SVR dengan nilai RMSE sebesar 0.0928, MAPE sebesar 14.32%, dan R² sebesar 0.6164. Model RNN kemudian diimplementasikan untuk memprediksi periode 3 bulan berikutnya. Hasil prediksi menunjukkan akan terjadi kenaikan produksi yang cukup signifikan di bulan pertama, kemudian mengalami sedikit penurunan dibulan kedua, dan mengalami kenaikan kembali dibulan ketiga.

Kata Kunci: Kelapa Sawit; Prediksi; Produksi; Recurrent Neural Network; Support Vector Regression

Abstract—Oil palm is one of the important plantation crops and a leading commodity in Indonesia. PT. XYZ is a company engaged in receiving Fresh Fruit Bunches (FFB) to be processed into Crude Palm Oil (CPO) and Palm Kernel (PK). So far, the company has conducted statistical analysis with a correction value of 5% - 12% on the production results each month in targeting production results. However, this method is still lacking, because it uses manual calculations and considers estimates from personal experience. Therefore, this research proposes a data mining technique with Support Vector Regression (SVR) and Recurrent Neural Network (RNN) algorithms to predict production output precisely. In this study, testing was carried out on SVR hyperparameters, namely Kernel, C, Gamma, and Epsilon. While in RNN, testing is carried out on the optimizer, and the learning rate. In addition, the window size is also determined through a series of experiments, namely 3, 5, and 7. The comparison results show that the RNN model outperforms SVR with an RMSE value of 0.0928, MAPE of 14.32%, and R² of 0.6164. The RNN model was then implemented to predict the next 3-month period. The prediction results show that there will be a significant increase in production in the first month, then a slight decrease in the second month, and an increase again in the third month.

Keywords: Palm Oil; Prediction; Production; Recurrent Neural Network; Support Vector Regression

1. PENDAHULUAN

Kelapa sawit adalah salah satu jenis tanaman perkebunan yang memiliki posisi penting di sektor pertanian khususnya di pulau Sumatera, Jawa, Kalimantan dan Papua yang menghasilkan minyak tertinggi di dunia [1]. Potensi tersebut juga menjadikan kelapa sawit menjadi komoditas unggulan di Indonesia [3]. Selain menjadi sub sektor yang penting, perkebunan sawit juga berkaitan dengan kegiatan transaksi ekspor dan impor yang menjadi sumber pendapatan devisa negara, menciptakan lapangan pekerjaan dan meningkatkan kesejahteraan masyarakat dalam proses pengelolaan produksi [4]. *Food and Agriculture Organization of The United Nations* mencatat bahwa kelapa sawit merupakan industri potensial yang menghasilkan produksi besar di pasar global [5].

PT. XYZ merupakan suatu perseroan terbatas (PT) bergerak dalam bidang penerimaan Tandan Buah Segar (TBS) Sawit yang kemudian diolah menjadi Crude Palm Oil (CPO) dan Palm Kernel (PK) dengan nama PKS-PT. PT. XYZ didirikan pada tanggal 08 September 2008 dan selanjutnya tanggal 11 Februari 2010 dimulai pembangunan PMKS (pabrik minyak kelapa sawit) dan baru beroperasi pada tanggal 09 April 2012. Pabrik tersebut didirikan diatas lahan seluas ± 14 Ha. Secara geografis, PKS ini dalam menjalankan aktivitas perusahaannya beralokasi di wilayah Desa Bukit Sembilan Kecamatan Bangkinang Kabupaten Kampar, Riau.

PT. XYZ dalam eksistensinya bertujuan melakukan dan menunjang kebijakan serta program pemerintah dibidang ekonomi dan pembangunan nasional umumnya dan khususnya subsector perkebunan yang menyangkut penyediaan *Crude Palm Oil dan Palm Kernel*. Serta berusaha mengikat marwah Melayu Riau dengan menjadi pelopor pembangunan Pabrik kelapa Sawit milik pribumi di bumi lancing kuning. Selain itu, Septa Group selaku induk dari PT. Mitra Bumi untuk jangka panjang juga memiliki keinginan yang kuat untuk dapat mendirikan industri hilir yang akan menghasilkan turunan dari CPO baik berupa Minyak Goreng, Odol, Sabun dan lain-lain. Sehingga kita tidak perlu mengekspor CPO ke luar negeri serta dapat memenuhi kebutuhan didalam negeri sendiri. Saat ini, PT, Mitra Bumi sudah mempunyai pabrik kelapa sawit di pasir pangaraiyan dan sedang membangun PKS dikabupaten Kuansing.

Hingga saat ini dalam menargetkan hasil produksi, perusahaan melakukan analisis statistik dengan nilai koreksi 5% - 12% pada hasil produksi setiap bulannya. Namun metode ini masih kurang dalam memberikan hasil prediksi

yang tepat, karena menggunakan perhitungan manual dan mempertimbangkan perkiraan dari pengalaman pribadi. Untuk itu diperlukan teknik prediksi yang tepat untuk mengatasi permasalahan dalam memprediksi hasil produksi secara akurat. Salah satu teknik yang dapat digunakan untuk menangani kasus tersebut adalah Data Mining.

Data mining merupakan teknik dalam pengolahan data yang menemukan hubungan dari data sehingga dapat dijadikan sebagai dasar dalam pengambilan keputusan [8]. Data mining adalah suatu proses yang mencari pola atau informasi menarik dalam data terpilih dengan menggunakan teknik atau metode tertentu. Teknik-teknik, metode-metode, atau algoritma yang tepat sangat bergantung pada tujuan dan proses Knowledge Discovery in Databases (KDD) [9]. Pada data mining terdapat metode yang dapat melakukan prediksi atau yang dikenal dengan regresi.

Regresi merupakan upaya memanfaatkan berbagai kumpulan data atau informasi yang relevan di masa sebelumnya untuk memperkirakan atau mengasumsikan sesuatu yang akan terjadi di masa yang akan datang melalui proses metode ilmiah yang sistematis [10]. Beberapa algoritma prediksi yang populer adalah *Support Vector Regression* (SVR) dan *Recurrent Neural Network* (RNN). Algoritma SVR bekerja dengan menemukan fungsi sebagai hyperplane berupa fungsi regresi yang mencocokkan seluruh data masukan dengan kesalahan sekecil mungkin [11]. Sementara itu RNN merupakan salah satu jenis jaringan syaraf tiruan yang mampu usntuk memproses data berurutan (sequential) dengan konteks temporal sehingga dapat digunakan pada data time series [12].

Terdapat beberapa penelitian sebelumnya yang berkaitan dengan penelitian ini. Penelitian pertama menggunakan algoritma SVR untuk prediksi produksi dan produktivitas kelapa sawit menghasilkan model dengan akurasi 75,4% [13]. Penelitian selanjutnya menggunakan algoritma LSTM untuk prediksi produksi kelapa sawit menghasilkan model dengan RMSE sebesar 0.1725 dan MAPE sebesar 50.87% [14]. Penelitian lainnya menggunakan moving average untuk prediksi produksi kelapa sawit menghasilkan model dengan MAPE sebesar 10% [15]. Berdasarkan penelitian tersebut maka penelitian tentang prediski produksi kelapa sawit masih perlu dibahas lebih lanjut dengan menguji teknik lain dan algoritma modern sehingga dapat mengasilkan model yang akurat.

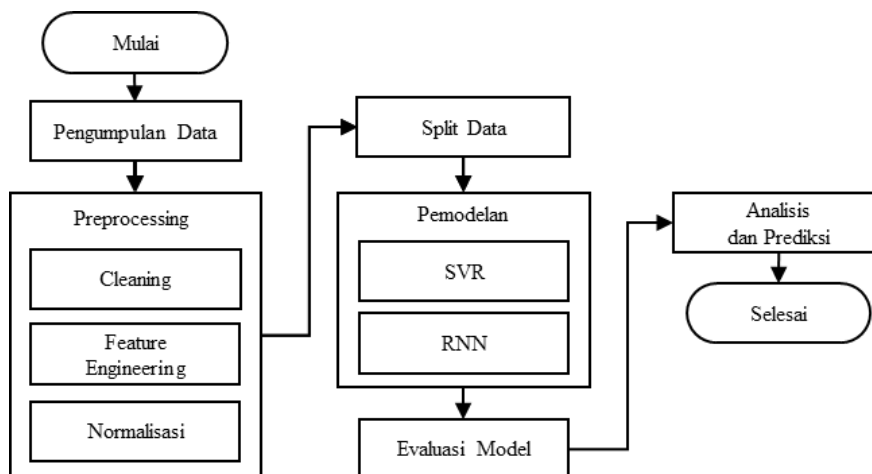
Perbedaan utama penelitian ini dengan penelitian sebelumnya adalah pada penelitian ini melakukan teknik feature engineering yang tidak digunakan pada penelitian sebelumnya [13]–[15] untuk memperkaya data sehingga memudahkan model menangkap pola unik. Lebih lanjut pada penelitian ini menggunakan empat kernel dari SVR (Linear, Polynomial, RBF, dan Sigmoid) sementara penelitian [13] hanya menggunakan tiga kernel (Linear, RBF, dan Polynomial). Kemudian pada penelitian ini menggunakan algoritma yang berbeda dibandingkan dengan penelitian [14] dan [15] untuk menguji seberapa baik model yang diusulkan yaitu RNN dalam menangani kasus yang sama.

Berdasarkan penjelasan tersebut maka penelitian melakukan prediksi produksi kelapa sawit menggunakan algortima *Support Vector Regression* (SVR) dan *Recurrent Neural Network* (RNN) di PT. XYZ. Tujuan dari penelitian ini adalah menghasilkan model prediksi yang akurat sehingga dapat membantu perusahaan dalam melakukan perencanaan produksi. Selain itu penelitian ini juga bertujuan untuk mengetahui bagaimana potensi algoritma SVR dengan RNN dalam melakukan prediksi produksi kelapa sawit. Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan efisiensi operasional perusahaan, terutama dalam merumuskan strategi produksi yang akurat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Seluruh proses dan tahapan dari penelitian ini digambarkan dengan lengkap melalui diagram alir yang dapat dilihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

Gambar 1 menjelaskan seluruh tahapan penelitian yang dimulai dengan mengumpulkan data secara langsung di PT. XYZ selama 5 tahun terakhir. Data kemudian akan dipreprocessing untuk memastikan stuktur dan format dari

data sudah sesuai dan konsisten. Data perlu dibagi menjadi dua bagian yaitu training dan testing. Selanjutnya pemodelan dilakukan menggunakan SVR dan RNN untuk mendapatkan model terbaik berdasarkan hasil evaluasi menggunakan metrik RMSE, MAPE dan R^2 . Terakhir, model terbaik akan digunakan untuk melakukan prediksi dan memproyeksikan bagaimana hasil produksi kelapa sawit dimasa mendatang selama 3 bulan berikutnya.

2.2 Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data time series produksi kelapa sawit yang diambil secara langsung di PT. XYZ selama (hampir) 5 tahun terakhir, mulai dari 1 Januari 2019 – 30 April 2023 dengan total 1612 baris data. Data ini berformat time series harian yang mencatat produksi kelapa sawit setiap harinya dalam satuan Ton. Selain itu, data ini bertipe univariate yang hanya memiliki fitur tanggal dan hasil produksi (TBS).

2.3 Preprocessing

2.3.1 Cleaning

Proses cleaning pada penelitian ini terdiri dari beberapa tahapan, yaitu mengubah format data menjadi bulanan dan menangani data yang hilang. Dataset diubah dalam format bulanan karena proses evaluasi dan perencanaan produksi kelapa sawit dilakukan setiap bulan. Selanjutnya, data tersebut juga perlu dilakukan pengecekan nilai yang hilang (missing value) untuk memastikan data dalam kualitas baik. Perlu diperhatikan bahwa tipe data sudah konsisten dan sesuai sehingga dapat diproses untuk tahap selanjutnya.

2.3.2 Feature Engineering

Feature engineering merupakan proses manipulasi atau pembuatan fitur-fitur baru dari data mentah. *Windowing* (dalam istilah lain time steps, sliding window, atau lainnya) merupakan teknik *feature engineering* yang digunakan untuk membentuk fitur historis pada data *time series*. Teknik ini umum digunakan pada data *time series univariate*. Pada penelitian ini *window size* ditetapkan melalui rangkaian percobaan yaitu 3, 5 dan 7 untuk mendapatkan hasil yang maksimal seperti yang dilakukan oleh penelitian [16] meskipun dengan nilai yang berbeda. Selain itu, untuk membentuk fitur temporal yang mewakili perubahan waktu pada data, maka akan dilakukan pembentukan fitur baru yaitu bulan dan tahun. Hal ini bertujuan untuk memperkaya fitur sehingga dapat memberikan informasi lebih dan meningkatkan kinerja model.

2.3.3 Normalization

Data yang telah diproses masih belum memiliki rentang nilai atau skala yang konsisten, sehingga perlu dilakukan proses normalisasi data. Proses ini dilakukan menggunakan salah satu teknik yang populer yaitu *min-max normalization*. Teknik ini akan mengubah rentang nilai pada data dalam skala 0-1 [17]. Implementasi *min-max normalization* dapat dilakukan menggunakan persamaan berikut.

2.4 Pembagian Data

Data perlu dibagi menjadi dua bagian, yaitu data latih (*training*) dan data uji (*testing*). Data pelatihan digunakan untuk melatih model agar dapat mengidentifikasi pola dalam data, sementara data pengujian digunakan untuk mengevaluasi dan menilai sejauh mana kemampuan model yang telah dilatih [18]. Proses pembagian data ini dilakukan menggunakan teknik *hold-out validation* karena cukup sederhana. Persentase pembagian data pada penelitian ini yaitu 80:20 yang artinya 80% dari total data akan dijadikan sebagai data latih dan lainnya sebagai data uji yaitu 20%.

2.5 Pemodelan

2.5.1 Support Vector Regression

Support Vector Regression (SVR) merupakan turunan dari algoritma *support vector machine* (SVM) yang khusus digunakan untuk kasus regresi dengan mengubah dengan menambahkan variabel baru yaitu epsilon [19]. Implementasi SVR dilakukan dengan menemukan fungsi sebagai hyperplane yaitu yang mencocokkan seluruh data input dengan nilai kesalahan seminimal mungkin [11]. Kelebihan dari algoritma SVR adalah dapat diterapkan pada data non-linear ataupun linear berdasarkan fungsi kernel [20], [21]. Kemudian, SVR mampu digunakan untuk kasus *time series* dengan dimensi tinggi [20] sehingga dapat menghindari *overfitting*. Beberapa kernel SVR yang populer yaitu kernel *linier*, *polinomial*, dan *Radial Basis Function* (RBF) atau *Gaussian* [22]. Namun SVR memiliki kelemahan, yaitu parameter yang kompleks sehingga sulit untuk memilih parameter yang tepat dan optimal [23].

$$f(x) = w^T \varphi(x) + b \quad (1)$$

2.5.2 Recurrent Neural Network

Recurrent Neural Network (RNN) merupakan salah satu jenis jaringan syaraf tiruan yang mampu untuk memproses data berurutan (sequential) dengan konteks temporal sehingga dapat digunakan pada data *time series* [12]. Peran yang signifikan dari RNN adalah dalam memori input dan menghasilkan output yang tepat sesuai dengan konteksnya. Kemampuan RNN untuk menyimpan informasi dari input dan mengeluarkan output yang sesuai dengan konteksnya

adalah aspek yang krusial. Memori internal menjadi fokus penting dalam RNN karena memungkinkannya untuk memprediksi kejadian selanjutnya. Karena alasan tersebut, RNN sangat sesuai untuk aplikasi pada deret waktu, audio, video, teks dan lainnya [24].

$$f(x) = \sum_{i=1}^n \alpha_i Kx_i x_j + b \tag{2}$$

2.6 Evaluasi Model

Model yang telah dilatih kemudian akan dievaluasi dengan menggunakan beberapa metrik, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan *R-squared* (R²).

Root Mean Square Error (RMSE) merupakan suatu parameter nilai akar kuadrat dari *Mean Square Error* (MSE) yang digunakan pada peramalan untuk menghitung nilai kesalahan atau perbedaan antara data prediksi dengan data sebenarnya [16], [25]. Untuk menghitung nilai RMSE dapat menggunakan persamaan 3.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \tag{3}$$

MAPE adalah rata-rata diferensiasi absolut dari nilai prediksi dan aktual, dinyatakan dalam persentase dari nilai aktual [16], [25]. Untuk menghitung nilai MAPE dapat menggunakan persamaan 4.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \tag{4}$$

R² yang merupakan metrik untuk menentukan besarnya variasi di dalam variabel dependen yang dijelaskan pada variabel independen, sehingga dapat digunakan untuk mengetahui seberapa baik model prediksi menjelaskan variasi data aktual. Untuk menghitung nilai R² dapat menggunakan persamaan 5.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \tag{5}$$

2.7 Analisa dan Prediksi Periode Berikutnya

Model dengan kemampuan prediksi terbaik yang dinilai berdasarkan metrik evaluasi akan dipilih dan diimplementasikan untuk memprediksi hasil produksi kelapa sawit pada periode berikutnya selama 3 bulan kedepan. Hasil prediksi ini akan dimanfaatkan sebagai rekomendasi untuk perusahaan dalam menyusun perencanaan strategis.

3. HASIL DAN PEMBAHASAN

Data yang telah dikumpulkan akan diubah formatnya dari time series harian menjadi bulanan. Hasilnya terjadi perubahan pada jumlah data yaitu dari 1612 menjadi 52 baris data. Selanjutnya dari hasil pengamatan, diketahui bahwa data ini tidak memiliki nilai yang hilang sehingga tidak perlu dilakukan penanganan khusus. Data yang digunakan pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Data Awal Penelitian

Bulan	Produksi (Ton)
2019-01	723,82
2019-02	648,76
2019-03	797,33
2019-04	784,7
...	...
2023-04	745,36

Tabel 1 merupakan data yang telah bersih dan telah sesuai format, namun perlu dilakukan feature engineering untuk memperkaya fitur dan memberikan informasi lebih pada model sehingga model dapat mempelajari pola pada data dengan baik. Tahap pertama adalah windowing dengan menguji beberapa window size yaitu 3, 4, dan 5. Selanjutnya adalah membentuk fitur temporal yaitu bulan dan tahun. Hasil feature engineering dapat dilihat pada Tabel 2.

Tabel 2. Hasil Feature Engineering

Bulan	Tahun	Produksi B-4	Produksi B-3	Produksi B-2	Produksi B-1	Produksi (y)
5	2019	723,82	648,76	797,33	784,7	880,59
6	2019	648,76	797,33	784,7	880,59	815,27
7	2019	797,33	784,7	880,59	815,27	822,76
8	2019	784,7	880,59	815,27	822,76	939,44
...

4	2023	884,02	828,01	729,13	821,46	745,36
---	------	--------	--------	--------	--------	--------

Tabel 2 menunjukkan hasil dari implementasi feature engineering sehingga dapat membantu model menangkap pola yang berharga. Data tersebut kemudian dinormalisasi untuk menyesuaikan rentang nilai dalam skala yang sama menggunakan teknik min-max normalization. Dengan teknik ini rentang nilai pada setiap fitur akan berada dalam skala 0-1. Hasil normalisasi data dapat dilihat pada Tabel 3.

Tabel 3. Hasil Normalisasi Data

Bulan	Tahun	X-4	X-3	X-2	X-1	Produksi
0,3636	0,0000	0,3590	0,1639	0,5499	0,5171	0,7663
0,4545	0,0000	0,1639	0,5499	0,5171	0,7663	0,5966
0,5455	0,0000	0,5499	0,5171	0,7663	0,5966	0,6160
0,6364	0,0000	0,5171	0,7663	0,5966	0,6160	0,9192
...
0,2727	1,0000	0,7752	0,6297	0,3728	0,6126	0,4149

Tabel 3 merupakan hasil dari proses normalisasi sehingga setiap fitur dari data kini memiliki rentang nilai yang sama. Selanjutnya, tahap pemodelan diawali dengan mengimplementasikan algoritma SVR terlebih dahulu. Pada algoritma SVR, terdapat beberapa parameter yang dapat dikonfigurasi untuk mendapatkan model dengan kemampuan prediksi yang maksimal. Detail dari hyperparameter yang digunakan dapat dilihat pada tabel 4.

Tabel 4. Hyperparameter Algoritma SVR

Parameter	Value
Kernel	Linear, Polynomial, RBF, Sigmoid
C	0.01, 0.1, 0.25, 0.5, 0.75, 1, 2, 3, 5, 10
Epsilon	0.001, 0.01, 0.1, 1
Gamma	0.01, 0.1, 0.25, 0.5, 0.75, 1, 2, 3, 5, 10

Tabel 4 merupakan hyperparameter yang digunakan untuk melatih model SVR dengan C, Epsilon, dan Gamma sebagai parameter yang akan difokuskan. Proses pemodelan dilakukan dengan menggunakan library dari scikit-learn, sementara itu implementasi hyperparameter dilakukan menggunakan grid-search. Hasil pemodelan kemudian dievaluasi menggunakan tiga metrik yaitu RMSE, MAPE dan R2 untuk mengetahui seberapa baik kemampuan model yang telah dilatih saat memprediksi data uji. Hasil evaluasi model SVR dapat dilihat pada Tabel 5.

Tabel 5. Hasil Evaluasi Model SVR

Window Size	Kernel	C	Epsilon	Gamma	RMSE	MAPE	R ²
3	Linear	2	0,01	0,1	0,1684	20,41%	0,2917
3	RBF	5	0,001	0,1	0,1632	20,02%	0,3093
3	Poly	0,75	0,001	0,25	0,1598	18,08%	0,3591
3	Sigmoid	0,75	0,001	0,5	0,1752	19,78%	0,1990
4	Linear	0,25	0,01	0,01	0,1668	19,23%	0,3440
4	RBF	1	0,01	0,25	0,1619	20,92%	0,2508
4	Poly	0,25	0,1	0,5	0,1805	18,86%	0,3721
4	Sigmoid	5	0,1	0,25	0,2045	17,96%	0,3580
5	Linear	0,75	0,01	0,01	0,1635	21,54%	0,2044
5	RBF	5	0,01	0,1	0,1664	22,56%	0,1322
5	Poly	0,5	0,1	0,5	0,1950	17,67%	0,4536
5	Sigmoid	2	0,01	0,25	0,1762	19,70%	0,2776

Tabel 5 menunjukkan hasil pelatihan dan evaluasi model SVR dengan beberapa uji coba hyperparameter. Berdasarkan hasil tersebut diketahui bahwa model SVR dengan window size = 5, kernel = Polynomial, C = 0.5, Epsilon = 0.1, dan Gamma = 0.5 dengan RMSE sebesar 0.1950, MAPE sebesar 17.67% dan R2 sebesar 0.4356. Dengan begitu diketahui bahwa semakin panjang window size yang ditetapkan pada SVR memberikan hasil yang semakin baik, khususnya pada kernel Polynomial.

Tahapan selanjutnya adalah melakukan pemodelan dengan menggunakan algoritma RNN. Sama seperti algoritma SVR, pada algoritma RNN juga dilakukan proses pengujian hyperparameter. Detail dari hyperparameter yang digunakan pada RNN dapat dilihat pada Tabel 6.

Tabel 6. Hyperparameter Algoritma RNN

Parameter	Value
Optimizer	Adam, RMSProp, Adamax
Learning Rate	0.01, 0.001, 0.0001

Batch Size	4
Epoch	100
Hidden Layer	2
Num of Unit	50


Tabel 6 menunjukkan parameter yang akan dikonfigurasi pada RNN yaitu optimizer, learning rate, batch size, hidden layer, num of unit layer, dan epoch. Pada implementasinya, pemodelan algoritma RNN dilakukan dengan menggunakan library tensorflow. Hasil pelatihan model RNN kemudian juga akan dievaluasi menggunakan metrik RMSE, MAPE dan R2. Hasil evaluasi model RNN dapat dilihat pada Tabel 7.

Tabel 7. Hasil Evaluasi Model RNN

Window Size	Optimizer	Learning Rate	RMSE	MAPE	R ²
3	Adam	0,01	0,1047	16,20%	0,5116
3	Adam	0,001	0,1022	16,46%	0,5345
3	Adam	0,0001	0,1013	14,35%	0,5428
3	RMSprop	0,01	0,119	18,06%	0,3691
3	RMSprop	0,001	0,1066	16,02%	0,4930
3	RMSprop	0,0001	0,1039	14,81%	0,5189
3	Adamax	0,01	0,1216	19,45%	0,3412
3	Adamax	0,001	0,1024	15,28%	0,5323
3	Adamax	0,0001	0,1061	16,41%	0,4980
4	Adam	0,01	0,1090	17,05%	0,4707
4	Adam	0,001	0,1067	15,56%	0,4929
4	Adam	0,0001	0,1042	16,70%	0,5163
4	RMSprop	0,01	0,1084	16,02%	0,4760
4	RMSprop	0,001	0,1069	16,58%	0,4908
4	RMSprop	0,0001	0,1083	17,50%	0,4772
4	Adamax	0,01	0,1024	15,40%	0,5328
4	Adamax	0,001	0,1139	18,11%	0,4220
4	Adamax	0,0001	0,0928	14,32%	0,6164
5	Adam	0,01	0,0974	15,65%	0,5772
5	Adam	0,001	0,1083	16,17%	0,4774
5	Adam	0,0001	0,1158	18,51%	0,4021
5	RMSprop	0,01	0,1310	19,62%	0,2354
5	RMSprop	0,001	0,1005	14,88%	0,5495
5	RMSprop	0,0001	0,1047	15,16%	0,5113
5	Adamax	0,01	0,1048	16,57%	0,5112
5	Adamax	0,001	0,1253	18,96%	0,3007
5	Adamax	0,0001	0,1130	17,87%	0,4304

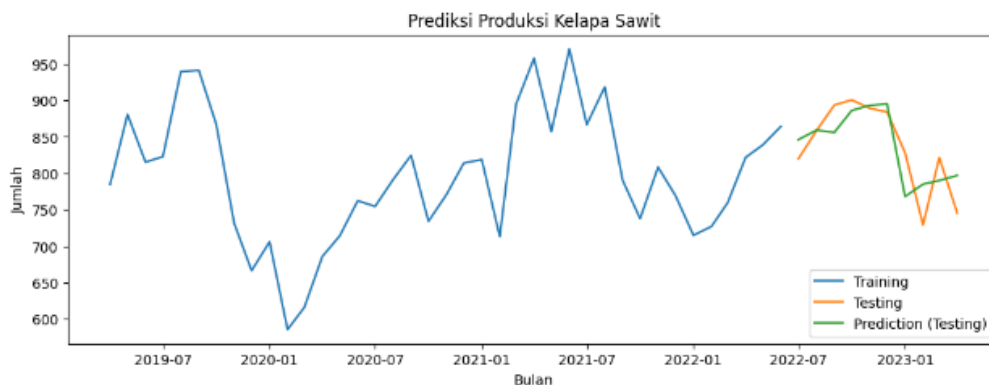
Tabel 7 merupakan hasil dari uji hyperparameter saat melakukan pelatihan model RNN. Hasilnya didapatkan bahwa model RNN dengan 4 window size, optimizer Adamax, dan learning rate 0.0001 sebagai model terbaik, dengan RMSE sebesar 0.0928, MAPE sebesar 14.32% dan R2 sebesar 0.6164. Dengan begitu diketahui bahwa meskipun optimizer Adam secara konsisten mendominasi dan stabil dalam memberikan hasil terbaik, tetapi Adamax lebih unggul pada parameter tertentu.

Selanjutnya, untuk mendapat model terbaik antara SVR dan RNN, maka perlu dilakukan perbandingan berdasarkan metrik RMSE, MAPE dan R2. Hasil perbandingan dapat divisualisasikan dengan diagram batang yang dapat dilihat pada Gambar 2.



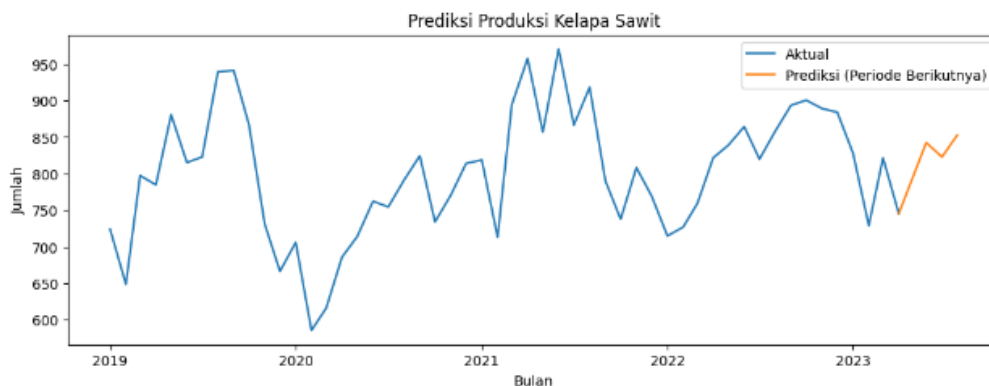
Gambar 2. Perbandingan SVR dan RNN

Gambar 2 menunjukkan hasil perbandingan dari algoritma SVR dan RNN berdasarkan metrik RMSE, MAPE dan R^2 . Hasil analisis mendapatkan bahwa model RNN dengan 4 window size, optimizer Adamax, dan learning rate 0.0001 jauh lebih baik dibandingkan dengan SVR, dengan RMSE sebesar 0.0924, MAPE 14.32% dan R^2 0.6164. Visualisasi hasil prediksi model terbaik pada data uji dapat dilihat pada Gambar 3.



Gambar 3. Hasil Prediksi Model Terbaik (RNN) pada Data Testing

Gambar 3 memperlihatkan bagaimana kemampuan model RNN dalam melakukan prediksi pada data testing. Terlihat bahwa hasil prediksi mampu mengikuti pola dari data testing dengan baik. Model tersebut kemudian diimplementasikan untuk memprediksi produksi kelapa sawit di masa mendatang pada periode 3 bulan berikutnya. Hasil prediksi ini dapat dilihat pada Gambar 4.



Gambar 4. Hasil Prediksi Model Terbaik (RNN) pada Periode Berikutnya (3 Bulan Kedepan)

Gambar 4 memperlihatkan bahwa model RNN memprediksi akan terjadi fluktuasi pada hasil produksi kelapa sawit selama periode 3 bulan kedepan. Dibulan pertama terjadi kenaikan yang cukup signifikan, kemudian dibulan kedua mengalami sedikit penurunan, dan dibulan ketiga mengalami kenaikan kembali. Kondisi seperti cuaca, pemeliharaan, serangan hama atau penyakit menjadi potensi utama yang menyebabkan produksi kelapa sawit dapat mengalami penurunan. Walaupun penurunan pada bulan kedua tidak terlalu signifikan, hal ini tetap perlu diperhatikan oleh manajemen perusahaan untuk mengantisipasi dampak terhadap perencanaan produksi.

Meskipun model yang dihasilkan sudah cukup baik, namun nilai kesalahan pada model masih perlu diperbaiki. Pemilihan optimizer, learning rate, dan window size menjadi aspek utama dalam meningkatkan kemampuan model RNN. Sementara itu pada SVR, kernel memiliki peran penting dalam menghasilkan model yang akurat. Meski pada kasus ini potensi RNN lebih baik dibandingkan SVR, kedua algoritma ini juga perlu di uji lebih lanjut pada data yang berbeda dengan kasus yang sama atau bahkan dengan data dan kasus yang berbeda.

Adapun batasan dari penelitian ini yaitu data yang digunakan di hanya diambil dari satu perusahaan sehingga hasilnya hanya dapat digunakan di dalam lingkup perusahaan tersebut. Selain itu jumlah data cukup sedikit terutama ketika diimplementasikan pada algoritma RNN yang berbasis deep learning, sehingga belum mampu melakukan prediksi jangka panjang dengan akurat. Untuk itu, penelitian berikutnya masih dapat menyempurnakan penelitian ini untuk menghasilkan model prediksi yang lebih akurat dengan menambahkan jumlah, teknik feature engineering lainnya, menggunakan algoritma yang lebih canggih, melakukan lebih banyak percobaan hyperparameter, dan implementasi teknik lainnya.

Hasil penelitian ini tentunya ini dapat dimanfaatkan oleh perusahaan dalam menyusun rencana strategis dan pengambilan keputusan, seperti manajemen pengelolaan, pemeliharaan tanaman, maupun inovasi teknologi produksi kelapa sawit untuk meningkatkan produktifitas. Dengan langkah strategis yang tepat, perusahaan dapat mencegah terjadinya penurunan hasil produksi kelapa sawit dan bahkan meningkatkan pertumbuhan bisnis.

4. KESIMPULAN

Perbandingan algoritma SVR dan RNN untuk prediksi produksi kelapa sawit menghasilkan akurasi prediksi yang cukup akurat. Hasil evaluasi menunjukkan bahwa RNN mengungguli SVR pada 4 window size dengan nilai RMSE sebesar 0.0924, MAPE sebesar 14.32% dan R2 sebesar 0.6164. Sementara itu SVR dengan window size = 5, kernel = Polynomial, C = 0.5, Epsilon = 0.1, dan Gamma = 0.5 hanya memiliki nilai RMSE sebesar 0.1950, MAPE sebesar 17.67% dan R2 sebesar 0.4356. Model RNN tersebut diimplementasikan untuk memprediksi periode 3 bulan berikutnya yang menunjukkan terjadi kenaikan yang cukup signifikan di bulan pertama, kemudian mengalami sedikit penurunan di bulan kedua, dan mengalami kenaikan kembali di bulan ketiga. Meskipun model yang dihasilkan sudah cukup baik, namun terdapat beberapa batasan dari penelitian ini. Beberapa diantaranya yaitu akurasi prediksi model masih belum maksimal dan juga masih belum dapat melakukan prediksi jangka panjang. Untuk itu, penelitian berikutnya dapat menyempurnakan penelitian ini dengan menambahkan jumlah data, menambahkan fitur yang relevan dan berkorelasi, menggunakan teknik feature engineering atau algoritma yang lebih canggih (seperti LSTM dan GRU), melakukan lebih banyak percobaan hyperparameter, dan implementasi teknik lainnya. Hasil penelitian ini dapat dimanfaatkan oleh perusahaan dalam menyusun rencana strategis dan pengambilan keputusan, seperti manajemen pengelolaan, pemeliharaan tanaman, maupun inovasi teknologi produksi kelapa sawit demi meningkatkan pertumbuhan bisnis atau mencegah terjadinya penurunan hasil produksi kelapa sawit.

REFERENCES

- [1] C. Michael, P. Marpaung, and F. Siburian, "Analisis Hubungan Biaya Produksi Kelapa Sawit Terhadap Pendapatan Petani di Desa Pulo Bayu Kecamatan Hutabayu Raja, Kabupaten Simalungun Organik," *Jurnal Agroteknosains*, vol. 4, no. pp. 8–16, 2020.
- [2] R. H. Fauzi, Y., Widyastuti, Y. E., Satyawibawa, I., & Paeru, "Kelapa sawit," Penebar Swadaya Grup, 2019.
- [3] A. Haryanti, N. Norsamsi, P. S. Fanny Sholiha, and N. P. Putri, "Studi Pemanfaatan Limbah Padat Kelapa Sawit," *Konversi*, vol. 3, no. 2, p. 20, 2019, doi: 10.20527/k.v3i2.161.
- [4] S. Hajar, A. A. Novany, A. P. Windarto, A. Wanto, and E. Irawan, "Penerapan K-Means Clustering pada ekspor minyak kelapa sawit menurut negara tujuan," *Seminar Nasional Teknologi Komputer & Sains (SAINTEKS) 2020*, pp. 314–318, 2020.
- [5] E. Wulansari, E. Yulianto, and E. Pangestuti, "Pengaruh Jumlah Produksi, Harga Internasional, Nilai Tukar dan Tingkat Suku Bunga Terhadap Tingkat Daya Saing Ekspor Kelapa Sawit Indonesia (Studi pada Tahun 2009-2013)," *Jurnal Administrasi Bisnis S1 Universitas Brawijaya*, vol. 39, no. 2, pp. 176–184, 2019.
- [6] BPDP, "Alat Cerdas deteksi kematangan buah kelapa sawit," 2018.
- [7] A. Agri, "Bagaimana minyak kelapa sawit dibuat?," 2019.
- [8] W. Muslehatin, M. Ibnu, and Mustakim, "Penerapan Naïve Bayes Classification untuk Klasifikasi Tingkat Kemungkinan Obesitas Mahasiswa Sistem Informasi UIN Suska Riau," *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri (SNTIKI)*, pp. 250–256, 2019.
- [9] Y. Mardi, "Data Mining : Klasifikasi Menggunakan Algoritma C4.5," *Edik Informatika*, vol. 2, no. 2, pp. 213–219, 2018, doi: 10.22202/ei.2016.v2i2.1465.
- [10] A. A. Fardhani, D. I. N. Simanjuntak, and A. Wanto, "Prediksi Harga Eceran Beras Di Pasar Tradisional Di 33 Kota Di Indonesia Menggunakan Algoritma Backpropagation," *Jurnal Infomedia*, vol. 3, no. 1, 2018, doi: 10.30811/jim.v3i1.625.
- [11] Q. Quan, Z. Hao, H. Xifeng, and L. Jingchun, "Research on water temperature prediction based on improved support vector regression," *Neural Computing and Applications*, vol. 34, no. 11, pp. 8501–8510, 2022, doi: 10.1007/s00521-020-04836-4.
- [12] A. A. Khozi, A. Aprianti, A. D. P. Dimas, and R. Fauzi, "Analisis Prediksi Data Kasus Covid-19 di Provinsi Lampung Menggunakan Recurrent Neural Network (RNN)," *Indonesian Journal of Applied Mathematics*, vol. 2, no. 1, p. 25, 2022, doi: 10.35472/indojam.v2i1.763.
- [13] A. Widiarni and M. Mustakim, "Penerapan Algoritma Support Vector Regression dalam Memprediksi Produksi dan Produktivitas Kelapa Sawit," *Jurnal Media Informatika Budidarma*, vol. 7, no. 2, pp. 864–872, 2023, doi: 10.30865/mib.v7i2.6089.
- [14] F. Husaini, I. Permana, M. Afdal, and F. N. Salisah, "Penerapan Algoritma Long Short-Term Memory untuk Prediksi Produksi Kelapa Sawit," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 2, pp. 366–374, 2024, doi: 10.57152/malcom.v4i2.1187.
- [15] F. Irawan, S. Sumijan, and Y. Yuhandri, "Prediksi Tingkat Produksi Buah Kelapa Sawit dengan Metode Single Moving Average," *Jurnal Informasi dan Teknologi*, vol. 3, pp. 251–256, 2021, doi: 10.37034/jidt.v3i4.162.
- [16] A. Rahmadayan and Mustakim, "Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction," *Procedia Computer Science*, vol. 234, pp. 204–212, 2024, doi: 10.1016/j.procs.2024.02.167.
- [17] D. Singh and B. Singh, "Investigating the impact of data normalization on classification performance," *Applied Soft Computing*, vol. 97, p. 105524, 2020, doi: 10.1016/j.asoc.2019.105524.
- [18] A. Rahmadayan, Mustakim, I. Ahmad, A. D. Alexander, and A. Rahman, "Phishing Website Detection with Ensemble Learning Approach Using Artificial Neural Network and AdaBoost," in *2023 International Conference on Information Technology Research and Innovation (ICITRI)*, 2023, pp. 162–166, doi: 10.1109/ICITRI59340.2023.10249799.
- [19] P. Bholia and S. Bhardwaj, "Estimation of solar radiation using support vector regression," *Journal of Information and Optimization Sciences*, vol. 40, no. 2, pp. 339–350, 2019, doi: 10.1080/02522667.2019.1578093.
- [20] S. Saadah, F. Z. Z., and H. H. Z., "Support Vector Regression (SVR) Dalam Memprediksi Harga Minyak Kelapa Sawit di Indonesia dan Nilai Tukar Mata Uang EUR/USD," *Journal of Computer Science and Informatics Engineering (J-Cosine)*, vol. 5, no. 1, pp. 85–92, 2021, doi: 10.29303/jcosine.v5i1.403.
- [21] R. E. Cahyono and J. P. Sugiono, "Analisis Kinerja Metode Support Vector Regression (SVR) dalam Memprediksi Indeks Harga Konsumen," *Jurnal Teknologi Informasi dan Multimedia*, vol. 1, no. 2, pp. 106–116, 2019, doi: 10.35746/jtim.v1i2.22.



- [22] Y. Yang, J. Che, C. Deng, and L. Li, “Sequential grid approach based support vector regression for short-term electric load forecasting,” *Applied Energy*, vol. 238, pp. 1010–1021, 2019, doi: 10.1016/j.apenergy.2019.01.127.
- [23] G. H. Saputra, A. H. Wigena, and B. Sartono, “Penggunaan Support Vector Regression Dalam Pemodelan Indeks Saham Syariah Indonesia Dengan Algoritme Grid Search,” *Indonesian Journal of Statistics and Its Applications*, vol. 3, no. 2, pp. 148–160, 2019, doi: 10.29244/ijsa.v3i2.172.
- [24] R. Al Kiramy, I. Permana, and A. Marsal, “Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT. Hajar Aswad,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1224–1234, 2024.
- [25] N. T. Luchia, E. Tasia, I. Ramadhani, A. Rahmadeyan, and R. Zahra, “Performance Comparison Between Artificial Neural Network, Recurrent Neural Network and Long Short-Term Memory for Prediction of Extreme Climate Change,” *Public Research Journal of Engineering, Data Technology and Computer Science*, vol. 1, no. 2, pp. 62–70, 2024, doi: 10.57152/predatecs.v1i2.864.